

SKRIPSI

**PERBANDINGAN METODE DECISION TREE REGRESSION
DAN RANDOM FOREST REGRESSION UNTUK
PEMELIHARAAN PREDIKTIF PADA PEMBANGKIT
LISTRIK TENAGA SURYA. (STUDI KASUS : PREDIKSI
DEGRADASI DAYA AKIBAT DEBU PADA PANEL SURYA)**

Disusun dan diajukan oleh:

**MOH. ABIB SAFAQDILLAH
D121 19 1026**



**PROGRAM STUDI SARJANA TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

LEMBAR PENGESAHAN SKRIPSI

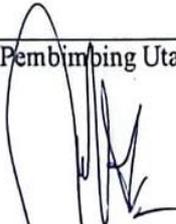
**PERBANDINGAN METODE DECISION TREE REGRESSION DAN
RANDOM FOREST REGRESSION UNTUK PEMELIHARAAN
PREDIKTIF PADA PEMBANGKIT LISTRIK TENAGA SURYA.
(STUDI KASUS : PREDIKSI DEGRADASI DAYA AKIBAT DEBU
PADA PANEL SURYA)**

Disusun dan diajukan oleh

Moh. Abib Safaqqillah
D121191026

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian
Studi Program Sarjana Program Studi Teknik Informatika
Fakultas Teknik Universitas Hasanuddin
Pada tanggal 05 Mei 2024
dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

<p>Pembimbing Utama,</p>  <p><u>Dr. Eng. Zulkipli Tahir, S.T., M.Sc</u> NIP 198404032010121004</p>	<p>Pembimbing Pendamping,</p>  <p><u>Prof. Dr. Ir. Syafruddin Syarif, M.T.</u> NIP 196111251988021001</p>
---	---



Ketua Program Studi,

Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus.Sys., IPM, ASEAN. Eng.
NIP 197507162002121004

PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini ;

Nama : Moh. Abib Safaqqillah
NIM : D121191026
Program Studi : Teknik Informatika
Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Perbandingan Metode Decision Tree Regression dan Random Forest Regression
untuk Pemeliharaan Prediktif pada Pembangkit Listrik Tenaga Surya. (Studi
Kasus : Prediksi Degradasi Daya Akibat Debu Pada Panel Surya)

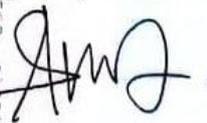
Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Semua informasi yang ditulis dalam skripsi yang berasal dari penulis lain telah diberi penghargaan, yakni dengan mengutip sumber dan tahun penerbitannya. Oleh karena itu semua tulisan dalam skripsi ini sepenuhnya menjadi tanggung jawab penulis. Apabila ada pihak manapun yang merasa ada kesamaan judul dan atau hasil temuan dalam skripsi ini, maka penulis siap untuk diklarifikasi dan mempertanggungjawabkan segala resiko.

Segala data dan informasi yang diperoleh selama proses pembuatan skripsi, yang akan dipublikasi oleh Penulis di masa depan harus mendapat persetujuan dari Dosen Pembimbing.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Gowa, 05 Mei 2024

g Menyatakan

METERAI
TEMPEL
14ALX119481360
Moh. Abib Safaqqillah

ABSTRAK

MOH ABIB SAFAQDILLAH. *Perbandingan Metode Decision Tree Regression dan Random Forest Regression untuk Pemeliharaan Prediktif pada Pembangkit Listrik Tenaga Surya. (Studi Kasus : Prediksi Degradasi Daya Akibat Debu Pada Panel Surya)* (dibimbing oleh Zulkifli Tahir dan Syafruddin Syarif)

Peningkatan fokus pada pemanfaatan energi terbarukan sebagai upaya untuk mengurangi emisi karbon dan menjaga lingkungan telah menjadikan Pembangkit Listrik Tenaga Surya (PLTS) sebagai salah satu teknologi utama dalam hal ini. Namun, menjaga efisiensi dan keandalan sistem PLTS tetap optimal merupakan tantangan utama. Salah satu penyebab penurunan produktivitas pada PLTS adalah akumulasi debu pada permukaan panel surya, yang dapat mengurangi efisiensi dalam mengubah energi matahari menjadi listrik. Oleh karena itu, perawatan yang baik dan teratur pada panel surya menjadi krusial untuk memastikan kinerja yang efisien. Meskipun tantangan dalam hal aksesibilitas mungkin memerlukan biaya dan waktu tambahan, namun pendekatan pemeliharaan prediktif dapat membantu mengurangi pengeluaran yang tidak perlu. Salah satu metode dari pemeliharaan prediktif adalah prediksi degradasi daya akibat debu pada panel surya. Metode ini didasarkan pada variabel-variabel yang memengaruhi keluaran daya pada panel surya, seperti suhu, kelembapan, intensitas cahaya matahari, konsentrasi debu, dan arus listrik. Dalam melakukan prediksi keluaran daya pada PLTS, digunakan dua metode yaitu Decision Tree Regression dan Random Forest Regression. Hasil dari penelitian menunjukkan bahwa model Random Forest Regression pada kondisi lingkungan minim debu memiliki nilai mse, rmse, dan mae berturut-turut sebesar 0,00248, 0,0498, dan mae 0,03912. Sementara pada kondisi lingkungan sangat berdebu, model ini memiliki nilai mse, rmse, dan mae sebesar 0,00173, 0,04159, dan mae 0,04061. Di sisi lain, model Decision Tree Regression menunjukkan nilai mse, rmse, dan mae berturut-turut sebesar 0,00261, 0,05116, dan 0,04055 pada kondisi lingkungan minim debu, serta nilai mse, rmse, dan mae sebesar 0,00181, 0,04263, dan 0,04164 pada kondisi lingkungan sangat berdebu.

Kata Kunci: PLTS, Prediksi, *Decision Tree Regression*, *Random Forest Regression*

ABSTRACT

MOH ABIB SAFAQDILLAH. *Comparison of Decision Tree Regression and Random Forest Regression Methods for Predictive Maintenance of Solar Power Plants. (Case Study: Prediction of Power Degradation Due to Dust on Solar Panels)* (supervised by Zulkifli Tahir and Syafruddin Syarif)

The increased focus on the utilization of renewable energy in an effort to reduce carbon emissions and safeguard the environment has made solar power generation (PLTS) one of the key technologies in this regard. However, keeping the efficiency and reliability of solar power systems optimized is a major challenge. One of the causes of decreased productivity in solar power plants is the accumulation of dust on the surface of solar panels, which can reduce their efficiency in converting solar energy into electricity. Therefore, proper and regular maintenance of solar panels is crucial to ensure efficient performance. While accessibility challenges may require additional cost and time, a predictive maintenance approach can help reduce unnecessary expenses. One method of predictive maintenance is the prediction of power degradation due to dust on solar panels. This method is based on variables that affect the power output of solar panels, such as temperature, humidity, sunlight intensity, dust concentration, and electric current. In predicting the power output of solar panels, two methods are used, namely Decision Tree Regression and Random Forest Regression. The results of the study show that the Random Forest Regression model in minimal dust environmental conditions has mse, rmse, and mae values of 0.00248, 0.0498, and mae 0.03912, respectively. While in very dusty environmental conditions, this model has mse, rmse, and mae values of 0.00173, 0.04159, and mae 0.04061. On the other hand, the Decision Tree Regression model shows mse, rmse, and mae values of 0.00261, 0.05116, and 0.04055 respectively in minimal dust environment conditions, and mse, rmse, and mae values of 0.00181, 0.04263, and 0.04164 in very dusty environment conditions.

Keywords: PLTS, Prediction, Decision Tree Regression, Random Forest Regression

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI	i
PERNYATAAN KEASLIAN.....	ii
ABSTRAK	iii
ABSTRACT	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR	vii
DAFTAR TABEL.....	viii
DAFTAR SINGKATAN DAN ARTI SIMBOL	ix
DAFTAR LAMPIRAN.....	x
KATA PENGANTAR	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Batasan Masalah Penelitian	4
BAB II TINJAUAN PUSTAKA.....	5
2.1 Pembangkit Listrik Tenaga Surya.....	5
2.2 Debu	7
2.3 Predictive Maintenance.....	8
2.4 Machine Learning	9
2.5 Decision Tree	10
2.6 Random Forest	12
2.7 MAE.....	13
2.8 RMSE.....	14
2.9 ESP32.....	15
2.10 Sensor DHT11.....	16
2.11 Sensor BH1750	16
2.12 Sensor INA219.....	17
2.13 Sensor GP2Y1010AU0F.....	19
BAB III METODE PENELITIAN.....	21
3.1 Waktu dan Lokasi Penelitian	21
3.2 Instrumen Penelitian	21
3.3 Tahapan Penelitian.....	22
3.4 Teknik Pengambilan Data.....	23
3.5 Pengumpulan Data	27
3.6 Perancangan Sistem Prediksi	30
3.7 Perancangan Sistem Prediksi Secara <i>Realtime</i>	36
BAB IV HASIL DAN PEMBAHASAN	39
4.1 Pengumpulan Data	39
4.2 Implementasi Sistem Prediksi.....	41
4.3 Perbandingan Kinerja Model	58
4.4 Implementasi Sistem Prediksi Secara <i>Realtime</i>	67
BAB V PENUTUP.....	69
5.1 Kesimpulan	69

5.2 Saran.....	70
Daftar Pustaka	71
Lampiran	75

DAFTAR GAMBAR

Gambar 2. 1	Contoh Decision Tree Biner (Song, Y. Y., & Ying, L. U., 2015)	11
Gambar 2. 2	Skema Random Forest (Liu et al., 2012).....	13
Gambar 2. 3	Varian ESP32 (Babiuch et al., 2019).....	15
Gambar 2. 4	Diagram Pin DHT11 (Rahaman, M. H., & Iqbal, T., 2020).....	16
Gambar 2. 5	Sensor BH1750 (Cheddadi et al., 2020).....	17
Gambar 2. 6	Sensor INA219 (Youssef Cheddadi et al., 2020)	18
Gambar 2. 7	Sensor gp2y1010au0f	19
Gambar 2. 8	Hubungan antara konsentrasi debu dan tegangan keluaran.....	20
Gambar 3. 1	Lokasi penelitian	21
Gambar 3. 2	Tahapan Penelitian	22
Gambar 3. 3	Rancangan Skema Pengambilan Data	24
Gambar 3. 4	Alur Pengambilan Data	25
Gambar 3. 5	Penempatan Panel Surya	26
Gambar 3. 6	Kondisi Panel Surya di Lingkungan yang Sangat Berdebu Hari Ke-15	26
Gambar 3. 7	Grafik Data Suhu	27
Gambar 3. 8	Grafik Data Kelembapan	28
Gambar 3. 9	Grafik Data Intensitas Cahaya Matahari	28
Gambar 3. 10	Grafik Konsentrasi Debu	29
Gambar 3. 11	Grafik Arus Listrik	29
Gambar 3. 12	Tahapan <i>Preprocessing</i>	30
Gambar 3. 13	Grafik Data Hilang	31
Gambar 3. 14	<i>Flowchart Training dan Testing</i>	34
Gambar 3. 15	Alur Kerja Sistem Prediksi <i>Realtime</i>	37
Gambar 3. 16	Rancangan Dashboard <i>Realtime</i> Prediksi.....	38
Gambar 3. 17	<i>Channel ID dan API Key</i>	38
Gambar 4. 1	Mengunduh Data	39
Gambar 4. 2	Hasil <i>Export</i> Data Kondisi Lingkungan yang Minim Debu.....	40
Gambar 4. 3	Hasil <i>Export</i> Data Kondisi Lingkungan yang Sangat Berdebu	40
Gambar 4. 4	Grafik Arus Listrik Lingkungan yang Minim Debu.....	59
Gambar 4. 5	Grafik dan Tren Data Arus Listrik Lingkungan yang Minim Debu	60
Gambar 4. 6	Grafik Persentase Produksi Arus Listrik Pada Kondisi Lingkungan yang Minim Debu	61
Gambar 4. 7	Grafik Tren Data Aktual dan Prediksi Kondisi Lingkungan yang Minim Debu.....	62
Gambar 4. 8	Grafik Arus Listrik Lingkungan yang Sangat Berdebu.....	63
Gambar 4. 9	Grafik dan Tren Data Arus Listrik Lingkungan yang Sangat Berdebu	64
Gambar 4. 10	Grafik Persentase Produksi Arus Listrik Pada Kondisi Lingkungan yang Sangat Berdebu	65
Gambar 4. 11	Grafik Tren Data Aktual dan Prediksi Kondisi Lingkungan yang Sangat Berdebu.....	66
Gambar 4. 12	Tampilan Website Dashboard	68

DAFTAR TABEL

Tabel 2. 1	Fitur Sensor INA219 (Youssef Cheddadi et al., 2020)	18
Tabel 3. 1	Waktu Pengumpulan Data.....	27
Tabel 4. 1	Potongan Data Kondisi Lingkungan Minim Debu Sebelum Diseleksi	41
Tabel 4. 2	Potongan Data Kondisi Lingkungan Sangat Berdebu Sebelum Diseleksi	42
Tabel 4. 3	Potongan Data Kondisi Lingkungan Minim Debu Setelah Diseleksi	42
Tabel 4. 4	Potongan Data Kondisi Lingkungan Sangat Berdebu Setelah Diseleksi	42
Tabel 4. 5	Potongan Data Kondisi Lingkungan Minim Debu Setelah Diseleksi	43
Tabel 4. 6	Potongan Data Kondisi Lingkungan Sangat Bedebu Setelah Diseleksi	44
Tabel 4. 7	Potongan Data Sebelum <i>Cleaning Data</i>	45
Tabel 4. 8	Potongan Data Sesudah <i>Cleaning Data</i>	45
Tabel 4. 9	Potongan Data Lingkungan Minim Debu Sebelum <i>Feature Selection</i>	46
Tabel 4. 10	Potongan Data Lingkungan Minim Debu Setelah <i>Feature Selection</i>	46
Tabel 4. 11	Potongan Data Lingkungan Sangat Berdebu Setelah <i>Feature</i> <i>Selection</i>	47
Tabel 4. 12	Potongan Data Lingkungan Minim Debu Sebelum Normalisasi	48
Tabel 4. 13	Potongan Data Lingkungan Minim Debu Setelah Normalisasi	49
Tabel 4. 14	Potongan Data Lingkungan Sangat Berdebu Sebelum Normalisasi	49
Tabel 4. 15	Potongan Data Lingkungan Sangat Berdebu Setelah Normalisasi	50
Tabel 4. 16	Pembagian Data <i>Training</i> dan <i>Testing</i>	50
Tabel 4. 17	Nilai <i>Default Hyperparameter Decision Tree Regression</i>	51
Tabel 4. 18	Performa Model dengan <i>Hyperparameter Default Decision Tree</i> <i>Regression</i>	52
Tabel 4. 19	Rentang Nilai <i>Hyperparameter Decision Tree Regression</i>	53
Tabel 4. 20	Nilai <i>Hyperparameter</i> Terbaik <i>Decision Tree Regression</i>	53
Tabel 4. 21	Performa Model dengan <i>Hyperparameter</i> Terbaik <i>Decision Tree</i> <i>Regression</i>	54
Tabel 4. 22	Nilai <i>Hyperparameter Default Random Forest Regression</i>	55
Tabel 4. 23	Performa Model dengan <i>Hyperparameter Default Random Forest</i> <i>Regression</i>	56
Tabel 4. 24	Rentang Nilai <i>Hyperparameter Random Forest Regression</i>	57
Tabel 4. 25	Nilai <i>Hyperparameter</i> Terbaik <i>Random Forest Regression</i>	57
Tabel 4. 26	Performa Model dengan <i>Hyperparameter</i> Terbaik <i>Random Forest</i> <i>Regression</i>	58
Tabel 4. 27	Perbandingan Kinerja Model.....	67

DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
PLTS	Pembangkit Listrik Tenaga Surya
IoT	<i>Internet of Things</i>
WSN	<i>Wireless Sensor Network</i>
DTR	<i>Decision Tree Regeression</i>
RFR	<i>Random Forest Regression</i>
PdM	<i>Predictive Maintenance</i>
MAE	<i>Mean Absolute Error</i>
MSE	<i>Mean Squared Error</i>
RMSE	<i>Root Mean Squared Error</i>
SdM	Sendok Makan

DAFTAR LAMPIRAN

Lampiran 1. Hasil Prediksi Model dan Data Aktual di Kondisi Lingkungan Minim Debu.....	75
Lampiran 2. Hasil Prediksi Model dan Data Aktual di Kondisi Lingkungan Sangat Berdebu.....	76
Lampiran 3. Source Code Pengambilan Data Arus Listrik.....	77
Lampiran 4. Source Code Pengambilan Data Suhu, Kelembaban, Intensitas Cahaya, dan Konsentrasi Debu.....	80
Lampiran 5. Source Code Pengambilan Data <i>Gateway</i>	83
Lampiran 6. Source Code <i>Preprocessing Data</i>	87
Lampiran 7. Source Code Pembuatan model dan Prediksi.....	90
Lampiran 8. Dataset	95
Lampiran 9. Source Code App.....	96
Lampiran 10. Source Code Tampilan <i>Realtime Monitoring</i> dan Prediksi Dashboard.....	98
Lampiran 11. Source Code Tampilan utama <i>Dashboard</i>	107
Lampiran 12. Alat dan Bahan.....	111
Lampiran 13. <i>Dashboard Realtime Monitoring</i> dan Prediksi	112

KATA PENGANTAR

Puji dan syukur penulis panjatkan atas kehadiran Allah SWT yang telah melimpahkan segala rahmat, berkah dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Perbandingan Metode Decision Tree Regression dan Random Forest Regression untuk Pemeliharaan Prediktif pada Pembangkit Listrik Tenaga Surya. (Studi Kasus : Prediksi Degradasi Daya Akibat Debu Pada Panel Surya)” sebagai salah satu syarat dalam menyelesaikan jenjang Strata-1 di Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin.

Dengan segala kerendahan hati, penulis menyadari bahwa dalam penyusunan dan penulisan laporan tugas akhir ini tidak lepas dari bantuan, bimbingan, serta dukungan dari berbagai pihak, dari masa perkuliahan hingga masa penyusunan tugas akhir. Oleh karena itu, pada kesempatan ini penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada :

1. Kedua orang tua penulis, Bapak Fathan dan Ibu Dewi Nuryani yang selalu memberikan doa, dukungan semangat, dan motivasi dalam menyelesaikan perkuliahan, serta selalu siap untuk memfasilitasi penulis dalam menjalankan dunia perkuliahan.
2. Bapak Dr. Eng. Zulkifli Tahir, S.T., M.Sc. selaku pembimbing I dan Bapak Prof. Dr. Ir. Syafruddin Syarif, M.T. selaku pembimbing II, yang senantiasa menyediakan waktu, tenaga, pikiran, dan perhatian yang luar biasa dalam mengarahkan penulis untuk menyelesaikan tugas akhir. Semoga Allah SWT membalas kebaikan dan dedikasi beliau dan menjadikan ilmunya bermanfaat.
3. Bapak Dr. Adnan, S.T., M.T. selaku Pembimbing Akademik penulis dan Bapak Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus.Sys., IPM, ASEAN. Eng. selaku ketua Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin.
4. Segenap dosen dan staf Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin yang telah membantu selama masa perkuliahan dan dalam penyelesaian tugas akhir.

5. Afwan, Albab, Boboy, Hijir, Iyad, Juan, Khalik, Sabda, Sayyid, Wira, Yoga, dan Zaki sebagai teman seperjuangan penulis di Teknik Informatika Unhas yang selalu membantu dan menemani satu sama lain.
6. Teman-teman S19NIFIER, dan teman-teman informatika kelas A yang telah memberi bantuan, dukungan, dan menemani selama masa perkuliahan.
7. Ilham dan Hedar yang selalu memberikan energi positif dan motivasi tambahan dalam berolahraga bersama, sehingga bukan hanya menguatkan fisik, tetapi juga membangun semangat juang dan ketahanan mental yang sangat diperlukan dalam menyelesaikan tugas akhir ini.
8. Serta seluruh pihak atas segala dukungan dan bantuannya yang tidak dapat penulis tuliskan satu persatu.

Pada akhirnya, dengan rendah hati, penulis mengakui adanya kekurangan dalam penyusunan tugas akhir ini. Oleh karena itu, penulis mengharapkan segala bentuk saran serta masukan yang membangun dari berbagai pihak. Semoga tugas akhir ini dapat memberikan manfaat dan kontribusi positif dalam bidang yang terkait.

Gowa, Mei 2024

Penulis

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penggunaan energi terbarukan semakin menjadi fokus utama dalam upaya mengurangi emisi karbon dan menjaga lingkungan hidup yang lebih baik. PLTS (Pembangkit Listrik Tenaga Surya) adalah salah satu teknologi energi terbarukan yang sangat menjanjikan untuk memenuhi kebutuhan listrik di banyak negara, termasuk Indonesia. PLTS memanfaatkan energi surya untuk menghasilkan listrik yang dapat digunakan oleh rumah tangga, perusahaan, maupun pemerintah. PLTS dapat diaplikasikan di berbagai lokasi, baik di daerah perkotaan maupun pedesaan, dan dapat beroperasi secara independen atau terhubung ke jaringan listrik utama.

Salah satu tantangan dalam penggunaan PLTS adalah menjaga efisiensi dan keandalan sistem tetap optimal. Penurunan produktivitas pada PLTS merupakan tanda terjadinya gangguan pada sistem, adanya debu yang menumpuk dan menempel pada permukaan panel surya merupakan salah satu penyebabnya. Debu dapat menghalangi cahaya matahari yang masuk, sehingga mengurangi efisiensi konversi energi sinar matahari menjadi listrik, pada hari yang cerah endapan debu dapat menurunkan transmitansi cahaya dari 94% menjadi menjadi 87,36% sedangkan pada hari berawan transmisi cahaya rata-rata menurun menjadi 51,4% (Wu, S. L. Et al., 2023). Hal ini dapat menyebabkan penurunan daya yang dihasilkan oleh panel surya, bahkan sampai dengan 20,2% tergantung dari tingkat kepekatan debu yang menempel (Abderrezzaq et al., 2017). Masalah ini menjadi semakin penting di daerah dengan tingkat polusi udara yang tinggi dan di daerah yang kering dengan angin kencang, di mana debu dan pasir dapat dengan mudah terangkat dan membawa debu ke panel surya, seperti penelitian yang dilakukan di Dhahran, Arab Saudi, menunjukkan bahwa penurunan daya sekitar 50% dapat terjadi mengacu pada modul PV ketika dibiarkan tidak dibersihkan selama 6 bulan (Adinoyi dan Said, 2013). Selain itu, lokasi yang terpencil dan sulit dijangkau seperti di atas atap gedung atau panel yang ditempatkan di lahan terbuka yang terpapar langsung ke lingkungan dapat meningkatkan risiko terhadap masalah debu.

Perawatan yang baik dan teratur harus dilakukan untuk menjaga panel surya agar tetap bersih dan bekerja secara efisien, yaitu dengan membersihkan panel surya secara rutin untuk menghilangkan debu yang menumpuk. Kendala aksesibilitas panel surya menjadi salah satu tantangan utama yang dihadapi ketika ingin melakukan pembersihan. PLTS yang sering kali menempatkan hamparan panel surya di atap bangunan tinggi, struktur yang curam, atau area terpencil sering kali memerlukan upaya ekstra untuk mencapainya. Penggunaan peralatan khusus atau teknik akses yang lebih kompleks diperlukan untuk mencapai panel-panel yang berada di lokasi yang sulit dijangkau. Tenaga kerja dan peralatan tambahan ini dapat meningkatkan biaya operasional secara signifikan. Selain itu, keterbatasan aksesibilitas juga dapat memperpanjang waktu yang dibutuhkan untuk menyelesaikan proses pembersihan, yang dapat meningkatkan biaya tenaga kerja dan memperpanjang periode *downtime* sistem PLTS. Dengan melakukan pemeliharaan prediktif pada panel surya yaitu melakukan pemeliharaan hanya pada saat dibutuhkan berdasarkan pemantauan secara terus-menerus dengan mengumpulkan dan menganalisis data dari peralatan atau sistem, sehingga dapat melakukan penjadwalan pemeliharaan (Çınar et al., 2020) dengan tujuan mengurangi pengeluaran biaya untuk pemeliharaan yang tidak perlu dilakukan.

Prediksi degradasi daya akibat debu pada panel surya adalah salah satu metode dari pemeliharaan prediktif yang dapat dilakukan untuk mengetahui waktu yang tepat melakukan pembersihan pada permukaan panel surya. Dalam melakukan prediksi keluaran daya pada PLTS, dapat digunakan beberapa metode seperti Decision Tree Regression, dan Random Forest Regression. Decision Tree Regression adalah algoritma machine learning dalam kategori supervised learning yang digunakan untuk melakukan klasifikasi atau regresi. Decision Tree Regression biasanya dibangun oleh prosedur rekursif yang mengoptimalkan kriteria pemisahan sesuai dengan dataset pelatihan yang secara rekursif dibagi menjadi dua atau lebih anak dari simpul akar (Yan et al., 2019). Random Forest Regression adalah algoritma machine learning yang digunakan dalam kategori supervised learning untuk melakukan klasifikasi, regresi, atau clustering. Random Forest Regression adalah kumpulan ensemble dari beberapa pohon yang dibangun dari sampel bootstrap, sehingga ketika membangun setiap pohon Random Forest Regression

mengambil rata-rata dari beberapa pohon berbeda untuk menghasilkan model yang kuat (Mohandoss et al., 2021). Perbedaan karakteristik dari kedua metode dapat mempengaruhi kinerja model dalam melakukan prediksi, sehingga perlu dilakukan perbandingan antara Decision Tree Regression, dan Random Forest Regression untuk dapat mengetahui kelebihan dan kekurangan masing-masing metode, serta performa dan akurasi prediksi yang dapat dicapai oleh setiap metode. Dengan demikian, dapat dipilih metode yang paling sesuai untuk memenuhi kebutuhan dan tujuan penggunaan pengaruh debu terhadap prediksi keluaran daya pada PLTS. Berdasarkan permasalahan sebelumnya, maka dilakukan penelitian dengan judul “Perbandingan Metode Decision Tree Regression dan Random Forest Regression Untuk Pemeliharaan Prediktif Pada Panel Surya”.

1.2 Rumusan Masalah

1. Bagaimana penerapan metode Decision Tree Regression, dan Random Forest Regression untuk prediksi degradasi daya akibat debu pada panel surya?
2. Bagaimana perbandingan tingkat keefektifan metode Decision Tree Regression, dan Random Forest Regression dalam memprediksi degradasi daya akibat debu pada panel surya?

1.3 Tujuan Penelitian

1. Dapat menerapkan algoritma Decision Tree Regression, dan Random Forest Regression untuk prediksi degradasi daya akibat debu pada panel surya.
2. Dapat membandingkan tingkat keefektifan algoritma Decision Tree Regression, dan Random Forest Regression dalam memprediksi degradasi daya akibat debu pada panel surya.

1.4 Manfaat Penelitian

1. Dapat menjadi pertimbangan dalam memilih metode yang tepat antara Decision Tree Regression dan Random Forest Regression untuk melakukan pemeliharaan prediktif dengan menggunakan prediksi degradasi daya akibat debu pada panel surya.

2. Dapat dijadikan sebagai referensi terkait perbandingan metode Decision Tree Regression dan Random Forest Regression dalam memprediksi degradasi daya akibat debu pada panel surya untuk penelitian lebih lanjut.

1.5 Batasan Masalah Penelitian

1. Pengambilan data dilakukan pada satu panel surya selama 30 hari.
2. Data yang diambil yaitu parameter suhu, kelembapan, intensitas cahaya matahari, konsentrasi debu, dan arus listrik.
3. Data yang digunakan yaitu data dengan interval waktu tiap 10 menit dan dalam 6 jam (09.00-15.00).
4. Mikrokontroler yang digunakan adalah ESP32.
5. Sensor yang digunakan yaitu sensor DHT11 untuk mengukur suhu dan kelembapan, sensor BH1750 untuk mengukur intensitas cahaya matahari, sensor INA219 untuk mengukur arus, dan sensor GP2Y1010AU0F untuk mengukur konsentrasi debu.
6. Metode yang digunakan yaitu Decision Tree Regression dan Random Forest Regression.

BAB II TINJAUAN PUSTAKA

2.1 Pembangkit Listrik Tenaga Surya

PLTS atau Pembangkit Listrik Tenaga Surya adalah sistem pembangkit listrik yang menggunakan energi matahari sebagai sumber energi untuk menghasilkan listrik. Cara kerja PLTS adalah dengan menangkap sinar matahari menggunakan panel surya dan mengubahnya menjadi listrik. Sel surya pada panel mengubah energi matahari menjadi energi listrik dalam bentuk arus searah (DC). Kemudian, inverter digunakan untuk mengonversi arus searah menjadi arus bolak-balik (AC) yang dapat digunakan untuk daya listrik biasa.

Pembangkit Listrik Tenaga Surya (PLTS) atau fotovoltaik adalah sistem pembangkit listrik yang menggunakan energi dari sinar matahari dengan mengubahnya melalui sel fotovoltaik. Kuantitas listrik yang dihasilkan oleh sistem ini bergantung pada tingkat radiasi matahari yang diterimanya. Secara umum, PLTS dapat dikelompokkan menjadi dua jenis berdasarkan cara kerjanya, yaitu PLTS off-grid dan PLTS on-grid. PLTS off-grid menggunakan baterai sebagai tempat penyimpanan energi sebelum listrik disalurkan ke konsumen, sedangkan PLTS on-grid terhubung ke jaringan listrik publik seperti PLN atau sistem jaringan lainnya, sering kali dalam bentuk hibrida. Dari perspektif desain, PLTS dapat diklasifikasikan sebagai PLTS terpusat atau PLTS tersebar. Dari segi lokasi pemasangan, PLTS dapat dipasang di atas tanah (ground mounted), di atap bangunan (PLTS Atap), atau bahkan di atas permukaan air (PLTS terapung). Perbedaan PLTS off-grid dan PLTS on-grid adalah pada komponen baterai dimana PLTS off-grid menggunakan baterai untuk menyimpan energi listrik sehingga dapat digunakan pada malam hari (Direktorat Aneka Energi Baru dan Energi, 2020).

Beberapa Komponen Sistem PLTS, sebagai berikut :

1. Panel Surya

Komponen utama dalam sistem PLTS adalah panel fotovoltaik, yang terdiri dari beberapa sel surya yang disusun bersama. Sel surya memiliki struktur dua lapisan semi konduktor yang memiliki muatan yang berbeda. Lapisan atas sel surya memiliki muatan negatif, sementara lapisan

bawahnya memiliki muatan positif. Sel-sel ini diposisikan secara sejajar dan dihubungkan secara seri dalam sebuah panel yang biasanya terbuat dari bahan seperti aluminium atau baja tahan karat, yang kemudian dilindungi oleh lapisan kaca atau plastik. Setiap sel surya juga dilengkapi dengan sambungan listrik agar dapat terhubung dengan sel surya lainnya (Hanna, 2012).

2. Inverter

Inverter adalah sebuah perangkat elektronik yang berperan dalam mengonversi arus searah (DC) menjadi arus bolak-balik (AC). Panel fotovoltaik dalam PLTS menghasilkan arus DC, oleh karena itu, dalam sistem PLTS, inverter menjadi komponen yang penting untuk mengubah energi ini agar dapat digunakan oleh perangkat- perangkat listrik yang menggunakan arus AC. Pemilihan inverter yang sesuai untuk suatu aplikasi tertentu akan bergantung pada kebutuhan daya beban yang akan dijalankan dan apakah inverter tersebut akan digunakan dalam sistem yang terhubung ke jaringan listrik utama atau dalam sistem mandiri yang berdiri sendiri (Elamim, 2018).

3. Solar Charge Controller

Solar Charge Controller adalah sebuah perangkat yang digunakan untuk mengatur proses pengisian baterai dari panel surya dan inverter. Terdapat dua jenis Solar Charge Controller, yaitu yang menggunakan teknologi PWM (pulse width modulation) dan MPPT (maximum power point tracking). Kontroler surya akan mengisi baterai dengan arus besar saat baterai dalam kondisi kosong, kemudian secara bertahap mengurangi arus pengisian saat baterai semakin terisi. Teknologi ini memastikan bahwa baterai terisi sepenuhnya tanpa menimbulkan tekanan berlebihan pada baterai. Setelah baterai mencapai kondisi penuh, kontroler surya akan menjaga agar baterai tetap terisi dengan tegangan float tertentu.

4. Baterai

Beberapa PLTS dilengkapi dengan baterai penyimpanan energi. Berfungsi untuk menyimpan energi listrik selama siang hari. Energi yang tersimpan akan dipakai pada saat malam atau bila energi dari PV tidak

mencukupi. Baterai juga membantu dalam mengurangi ketergantungan pada grid listrik. Berdasarkan aplikasinya maka baterai dibedakan untuk automotif, marine dan deep cycle. Deep cycle itu meliputi baterai yang biasa digunakan untuk photovoltaic dan backup power. Sedangkan secara konstruksi maka baterai dibedakan menjadi tipe basah, gel dan AGM (Absorbed Glass Mat). Baterai jenis AGM biasanya juga dikenal dengan VRLA (Valve Regulated Lead Acid). Baterai kering deep cycle juga dirancang untuk menghasilkan tegangan yang stabil. Penurunan kemampuannya tidak lebih dari 1-2% per bulan tanpa perlu *discharge* (Zhu H., 2015).

2.2 Debu

Debu adalah segala zat yang menyebar di udara yang meliputi partikel tanah dan debu (debu tersuspensi), asap, kabut, dan partikel. Debu terbentuk dari zat organik dan anorganik yang berasal dari bumi. Zat-zat tersebut meliputi badai pasir, asap pabrik, bakteri, serbuk sari, kebakaran hutan, dan uap gunung berapi. Selain itu, debu termasuk partikel atmosfer padat yang tetap tersuspensi di udara untuk waktu yang lama, dan mampu bergerak mengikuti pergerakan angin dalam jarak yang jauh (Kazem et al., 2014).

Debu dapat memiliki beberapa pengaruh yang signifikan terhadap sistem Pembangkit Listrik Tenaga Surya (PLTS). Salah satu dampak utamanya adalah mengurangi efisiensi PLTS. Debu yang menumpuk pada panel surya dapat memblokir cahaya matahari yang jatuh ke permukaan panel, sehingga mengurangi jumlah energi yang dapat dikumpulkan dan dikonversi menjadi listrik, bahkan sampai dengan 20,2% tergantung dari tingkat kepekatan debu yang menempel (Abderrezzaq dkk., 2017). Di daerah dengan tingkat polusi udara yang tinggi dan di daerah yang kering dengan angin kencang, di mana debu dan pasir dapat dengan mudah terangkat dan membawa debu ke panel surya, dapat menyebabkan penurunan daya sekitar 50% apabila dibiarkan tidak dibersihkan selama 6 bulan (Adinoyi dan Said, 2013). Karena itu, panel surya perlu secara rutin dibersihkan dari debu agar tetap beroperasi pada tingkat efisiensi yang optimal.

Selain itu, debu juga dapat mengakibatkan kerusakan fisik pada komponen PLTS, terutama jika debu tersebut berisi partikel abrasif yang dapat menggores permukaan panel surya atau komponen lainnya. Debu yang menempel pada panel surya juga dapat meningkatkan suhu operasional, karena mereka menghalangi transfer panas. Hal ini dapat mengurangi umur layanan panel surya dan meningkatkan biaya pemeliharaan.

2.3 Predictive Maintenance

Predictive Maintenance (PdM), atau Pemeliharaan Prediktif, adalah strategi pemeliharaan yang bertujuan untuk mencegah kerusakan atau kegagalan peralatan dengan cara memperkirakan kapan peralatan tersebut memerlukan pemeliharaan berdasarkan data, pemantauan terus-menerus, dan analisis.

PdM singkatan dari *Predictive Maintenance* adalah metode pemeliharaan berbasis statistik di mana jadwal pemeliharaan ditentukan hanya ketika diperlukan. Hal ini bergantung pada pemantauan terus menerus terhadap peralatan atau mesin. Pemeliharaan prediktif dengan menggunakan sistem prediksi bertujuan untuk mengevaluasi kapan tindakan pemeliharaan diperlukan, sehingga memungkinkan pemeliharaan terencana. Selain itu, dapat memungkinkan deteksi dini kesalahan berdasarkan data historis, dengan pemanfaatan sistem prediksi seperti metode pembelajaran mesin, faktor integritas (seperti aspek visual, perubahan warna dibandingkan dengan aslinya, asal usul, keausan), metode inferensi statistik, dan teknik rekayasa (Çınar et al., 2020).

Pemeliharaan prediktif dimulai dengan pengumpulan data dari perangkat atau mesin yang dipantau. Diperlukan sensor dan peralatan monitoring khusus untuk mengumpulkan data secara terus menerus dan kemudian mengirimkannya ke sistem monitoring. Data yang dikumpulkan dianalisis menggunakan berbagai teknik termasuk analisis statistik, metode pembelajaran mesin, dan algoritma kecerdasan buatan. Analisis ini digunakan untuk mengidentifikasi pola yang menunjukkan tanda-tanda awal potensi masalah atau kegagalan. Berdasarkan analisis data, dibuatlah sistem prediksi yang dapat memprediksi kapan suatu perangkat atau mesin akan mengalami kegagalan atau estimasi waktu yang tepat atau rentang waktu di mana pemeliharaan perlu dilakukan.

Bentuk pemeliharaan prediktif pada Pembangkit Listrik Tenaga Surya (PLTS) secara matematis dapat mengevaluasi sebelum terjadi resiko kegagalan komponen pada sistem, dengan mempertimbangkan data dari pemantauan secara terjadwal. Data yang dikumpulkan dapat menghasilkan rencana prediktif untuk melakukan rutinitas pemeliharaan, untuk mengurangi cacat berbahaya atau kegagalan sistem yang akan terjadi di masa mendatang saat sistem masih bekerja. Pemeliharaan ini sangat menurunkan biaya pasca pemeliharaan dan mencegah kegagalan yang lebih besar (Osmani et al., 2020).

2.4 Machine Learning

Teknologi yang sedang berkembang yang disebut machine learning memungkinkan komputer untuk belajar secara mandiri dari data historis. Pembelajaran mesin menggunakan berbagai teknik untuk membuat model matematika dan membuat prediksi berdasarkan informasi atau data sebelumnya. Saat ini, machine learning digunakan untuk berbagai hal, termasuk sistem rekomendasi, penyaringan email, penandaan otomatis Facebook, identifikasi gambar, dan pengenalan suara (Carbonell et al., 1983).

Algoritma machine learning membuat model matematika dengan bantuan data sampel historis, atau "data pelatihan", yang membantu dalam membuat prediksi atau penilaian tanpa diprogram secara eksplisit. Ilmu komputer dan statistik digunakan dengan machine learning untuk membuat model prediksi. Algoritma yang belajar dari data masa lalu dibuat oleh pembelajaran mesin atau digunakan di dalamnya (Maleki et al., 2020). Performanya akan semakin tinggi ketika semakin banyak informasi yang diberikan.

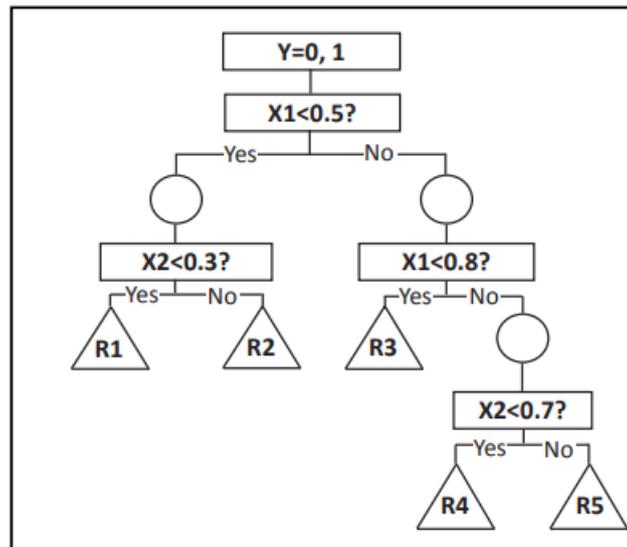
Setiap kali data baru diterima, sistem machine learning memprediksi hasilnya dengan belajar dari data historis, membuat model prediksi, dan belajar dari data masa lalu. Volume data yang digunakan untuk mengembangkan model memengaruhi seberapa baik model tersebut memprediksi keluaran, karena volume data yang lebih besar memungkinkan konstruksi model yang lebih akurat (Shaveta, 2023).

2.5 Decision Tree

Decision Tree adalah struktur data dengan bentuk pohon yang terdiri dari banyak node dan cabang dengan variasi pada setiap node. Dalam hal ini, node dengan cabang keluar disebut node internal, dan node lainnya disebut daun. Fungsi utama dari pohon keputusan adalah untuk membagi contoh data untuk regresi atau klasifikasi menjadi dua atau lebih kelompok berdasarkan aturan yang diterapkan pada node internal. Pemisahan ini didasarkan pada nilai-nilai variabel masukan yang dievaluasi dengan mempertimbangkan fungsi khusus yang didefinisikan selama tahap pelatihan model (Loh, 2011).

Stimulan dari pohon keputusan adalah algoritma yang menghasilkan pohon keputusan dari contoh yang diberikan. Algoritma ini bertujuan untuk menemukan pohon keputusan yang optimal dengan mengurangi fungsi kecocokan. Pada kasus regresi dataset yang digunakan tidak memiliki kelas, sehingga model regresi diterapkan pada variabel target menggunakan masing-masing variabel independen. Dataset dipisah menjadi beberapa titik pemisahan untuk setiap variabel independen. Pada setiap titik pemisahan, algoritma yang digunakan menghitung kesalahan antara nilai yang diprediksi dan nilai aktual berdasarkan fungsi kecocokan yang telah ditentukan. Kesalahan pemisahan pada berbagai variabel dibandingkan, dan variabel yang menghasilkan nilai fungsi kecocokan terendah dipilih sebagai titik pemisahan. Proses ini berlanjut secara berulang (Pekel E., 2020).

Algoritma ini bersifat non-parametrik, sehingga secara efisien dapat menangani kumpulan data yang besar dan rumit tanpa menerapkan struktur parametrik yang rumit. Apabila ukuran sampel cukup besar, data penelitian dapat dibagi menjadi kumpulan data pelatihan dan validasi. Dengan menggunakan kumpulan data pelatihan untuk membangun model Decision Tree dan kumpulan data validasi untuk menentukan ukuran pohon yang sesuai yang diperlukan untuk mencapai model akhir yang optimal (Song, Y. Y., & Ying, L. U., 2015).



Gambar 2. 1 Contoh Decision Tree Biner (Song, Y. Y., & Ying, L. U., 2015)

Pada gambar 2. 1 mengilustrasikan model Decision Tree sederhana yang mencakup satu variabel target biner Y (0 atau 1) dan dua variabel kontinu, x_1 dan x_2 , yang berkisar dari 0 hingga 1.

Komponen utama model pohon keputusan adalah sebagai berikut.

1. Simpul

Ada tiga jenis node. (a) Simpul akar atau simpul keputusan, merupakan pilihan yang akan menghasilkan pembagian semua catatan menjadi dua atau lebih subset yang saling eksklusif. (b) Simpul internal, atau simpul peluang, merupakan salah satu kemungkinan pilihan yang tersedia pada titik tersebut dalam struktur pohon; tepi atas simpul terhubung ke simpul induknya dan tepi bawah terhubung ke simpul anak atau simpul daunnya. (c) Simpul daun atau simpul akhir, merupakan hasil akhir dari kombinasi keputusan atau peristiwa (Song, Y. Y., & Ying, L. U., 2015).

2. Cabang

Cabang merupakan hasil atau kejadian kebetulan yang berasal dari simpul akar dan simpul internal. Model Decision Tree dibentuk menggunakan hierarki cabang. Setiap jalur dari simpul akar melalui simpul internal ke simpul daun mewakili aturan keputusan klasifikasi. Jalur Decision Tree ini juga dapat direpresentasikan sebagai aturan 'jika-maka'.

Misalnya, "jika kondisi 1 dan kondisi 2 dan kondisi ... dan kondisi k terjadi, maka hasil j terjadi" (Song, Y. Y., & Ying, L. U., 2015).

2.6 Random Forest

Random Forest, diperkenalkan oleh Breiman pada tahun 2001 (Louppe, 2014), merupakan algoritma supervised learning yang umumnya digunakan untuk menangani permasalahan klasifikasi, regresi, dan sejenisnya. Terdapat dua aspek yang memberikan ciri "random" pada algoritma ini, yaitu setiap pohon tumbuh pada sampel bootstrap yang berbeda, diambil secara acak dari data pelatihan, dan saat membagi setiap node selama pembentukan pohon keputusan, sebagian sampel dari n variabel dipilih secara acak dari dataset asli, dan yang terbaik digunakan dalam node tersebut.

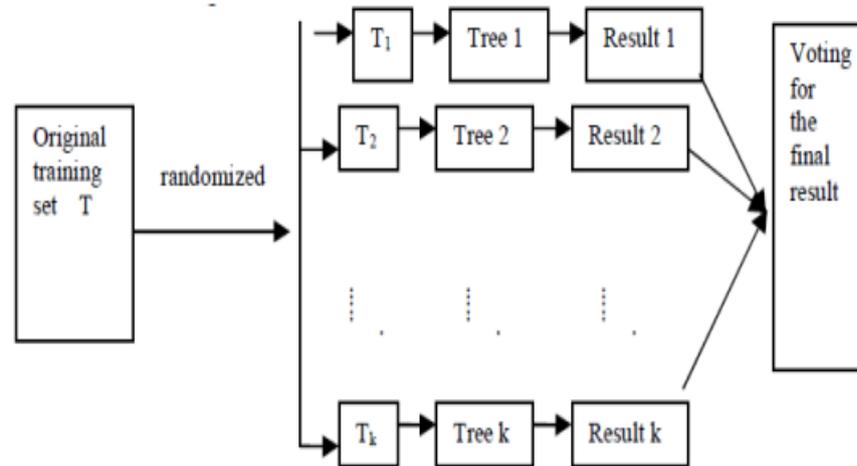
Menurut Leo Breiman (2001), Random Forest adalah pengklasifikasi yang terdiri dari kumpulan pohon pengklasifikasi yang terstruktur $\{h(x, \Theta_k), k=1, \dots\}$ dimana $\{\Theta_k\}$ vektor independen acak yang terdistribusi secara identik dan setiap pohon memberikan suara dengan nilai satu untuk kelas yang paling populer pada input x .

Definisi ini menunjukkan bahwa Random Forest (RF) adalah gabungan dari banyak klasifikasi berstruktur pohon. Dalam model RF Breiman, setiap pohon ditanamkan berdasarkan sampel pelatihan dan variabel acak. Variabel acak yang sesuai dengan pohon ke- k disimbolkan sebagai Θ_k . Dua variabel acak ini independen dan identik terdistribusi. Hal ini menghasilkan suatu klasifikasi $h(x, \Theta_k)$ di mana x adalah vektor input. Setelah dijalankan sebanyak k kali, maka didapatkan urutan klasifikasi $\{h_1(x), h_2(x), \dots, h_k(x)\}$, dan menggunakan ini untuk membentuk lebih dari satu sistem model klasifikasi. Hasil akhir dari sistem ini ditentukan dengan mayoritas suara biasa, dan fungsi keputusannya adalah

$$H(x) = \arg \max_Y \sum_{i=1}^k I(h_i(x) = Y) \quad (2.1)$$

Dimana $H(x)$ adalah kombinasi dari model klasifikasi, " h_i " adalah model pohon keputusan tunggal, " Y " adalah variabel output, dan " $I(\cdot)$ " adalah fungsi indikator. Untuk variabel input tertentu, setiap pohon memiliki hak untuk

memberikan suara dalam pemilihan hasil klasifikasi terbaik. Proses yang lebih spesifik ditunjukkan dalam Gambar 2. 2.



Gambar 2. 2 Skema Random Forest (Liu et al., 2012)

Random Forest adalah sekelompok Decision Tree. Decision Tree adalah pembelajar dasar dalam Random Forest. Decision Tree ditanam dengan memanfaatkan data pelatihan. Decision Tree memiliki kelemahan karena terlalu menyesuaikan model dengan data pelatihan. Random Forest mengatasi kelemahan ini dengan banyak Decision Tree. Semua Decision Tree ini, di Random Forest, melakukan polling selama prediksi dan sebagian besar jajak pendapat dianggap sebagai hasil prediksi. Jajak pendapat dari beberapa Decision Tree ini menghilangkan kesesuaian beberapa pohon keputusan dengan data pelatihan (Murphy A., & Moore C., 2019).

2.7 MAE

MAE adalah singkatan dari Mean Absolute Error. Ini adalah ukuran statistik yang digunakan untuk mengukur besarnya rata-rata kesalahan dalam kumpulan prediksi atau perkiraan. MAE dihitung dengan mengambil rata-rata dari selisih absolut antara nilai-nilai yang diprediksi dan nilai-nilai aktual (Willmott, C. J., & Matsuura, K, 2005).

Cara menghitung MAE adalah dengan menjumlahkan selisih absolut (nilai positif) antara setiap nilai aktual (y) dan nilai yang diprediksi oleh model (\hat{y}) untuk

semua titik data, lalu membaginya dengan jumlah total titik data (n). Berikut adalah formula matematika untuk MAE.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.2)$$

Dimana :

MAE = mean absolute error

n = jumlah total data

y_i = nilai aktual untuk data ke-i

\hat{y}_i = nilai prediksi untuk data ke-i

Nilai MAE yang rendah mengindikasikan bahwa besarnya rata-rata kesalahan dalam prediksi adalah kecil. Hal ini berarti prediksi mendekati nilai-nilai aktual yaitu menunjukkan tingkat akurasi yang lebih tinggi dalam model atau metode prediksi tersebut (Willmott, C. J., & Matsuura, K, 2005).

2.8 RMSE

RMSE adalah singkatan dari Root Mean Square Error atau akar dari MSE merupakan metrik yang umum digunakan untuk mengevaluasi kinerja model. MSE mengukur besarnya rata-rata dari kuadrat selisih antara nilai-nilai yang diprediksi dan nilai-nilai aktual, sedangkan RMSE dihitung dengan mengambil akar kuadrat dari rata-rata dari selisih kuadrat antara nilai yang diprediksi dan nilai yang sebenarnya (Hodson, T. O., 2022).

Secara matematis, RMSE dihitung sebagai berikut:

$$RMSE = \sqrt{MSE} \quad (2.3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (2.4)$$

Dimana :

RMSE = nilai root mean square error

y = nilai aktual

\hat{y} = nilai hasil prediksi

n = jumlah data

Keunggulan RMSE dibandingkan dengan MAE adalah bahwa RMSE memberikan bobot lebih besar pada kesalahan yang lebih besar. Hal ini terjadi karena RMSE mengkuadratkan selisih antara nilai-nilai yang diprediksi dan aktual sebelum mengambil rata-rata, sementara MAE hanya mengambil selisih absolut. Dengan mengkuadratkan kesalahan, RMSE memberikan hukuman yang lebih berat pada kesalahan yang lebih besar, sehingga menjadi lebih sensitif terhadap outlier atau nilai ekstrim. Ini dapat bermanfaat dalam aplikasi tertentu di mana kesalahan besar dianggap lebih kritis atau perlu diminimalkan (Hodson, T. O., 2022).

2.9 ESP32

ESP32 adalah sebuah mikrokontroler yang memiliki kemampuan jaringan Wi-Fi dan Bluetooth. Mikrokontroler ini dikembangkan oleh perusahaan Espressif Systems dan memiliki beberapa versi yang berbeda, seperti ESP32 Developer Kit, ESP32 Wrover Kit, dan ESP32 Azure IoT kit. ESP32 memiliki dua inti prosesor yang dapat dikontrol secara independen, serta dilengkapi dengan berbagai fitur dan periferal seperti sensor suhu, sensor sentuh, dan akselerometer. Mikrokontroler ini juga memiliki kemampuan kriptografi dan generator angka acak. ESP32 dapat digunakan dalam berbagai aplikasi seperti smart home, otomasi, wearable devices, dan aplikasi IoT berbasis cloud (Babiuch et al., 2019).



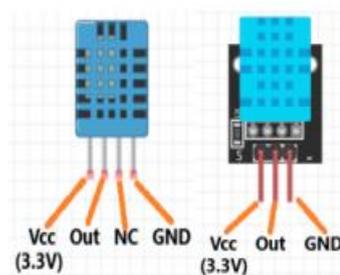
Gambar 2. 3 Varian ESP32 (Babiuch et al., 2019)

ESP32 adalah serangkaian mikrokontroler sistem-on-chip (SoC) yang dirancang untuk proyek Internet of Things (IoT) dan sistem tertanam. Mikrokontroler ini memiliki kemampuan Wi-Fi dan Bluetooth, serta struktur yang

sangat terintegrasi dengan didukung oleh prosesor mikro Tensilica Xtensa LX6 dual-core (Maier et al., 2017).

2.10 Sensor DHT11

Modul ini memiliki kompleksitas kelembapan dan suhu dengan output sinyal digital yang telah dikalibrasi, artinya modul sensor DHT11 merupakan modul gabungan untuk mendeteksi kelembapan dan suhu yang menghasilkan sinyal keluaran digital yang telah dikalibrasi. DHT11 memberikan nilai kelembapan dan suhu yang sangat akurat dan menjamin keandalan tinggi serta stabilitas jangka panjang. Sensor ini memiliki komponen pengukuran kelembapan tipe resistif dan komponen pengukuran suhu tipe NTC dengan mikrokontroler 8-bit terintegrasi yang memiliki respons cepat dan hemat biaya, serta tersedia dalam kemasan 4-pin (Srivastava et al., 2018), dan 3-pin dalam satu baris.



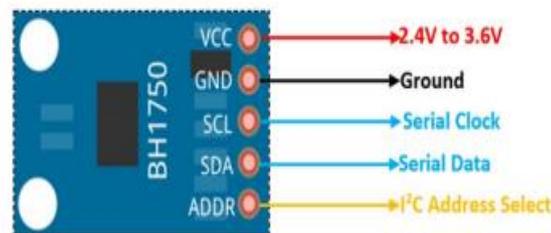
Gambar 2. 4 Diagram Pin DHT11 (Rahaman, M. H., & Iqbal, T., 2020)

Pin Out (data) terhubung dengan pin masukan digital mikrokontroler, pin VCC dengan tegangan 3,5 – 5 volt DC yang dihubungkan ke pin power, pin NC (Not Connection) tidak digunakan, dan pin GND dihubungkan ke pin ground.

2.11 Sensor BH1750

Modul sensor BH1750 merupakan sebuah sensor cahaya digital GY-302 dengan menggunakan antarmuka IC12 yang bersifat sensitif terhadap intensitas cahaya yang berada disekitarnya dan sensor cahaya terintegrasi yang terdiri atas sensor foto dioda, pengkondisi sinyal, analog to digital converter (ADC), dan rangkaian antarmuka dengan protokol komunikasi I2C (inter integrated circuit). Modul ini menggunakan sensor fotodioda dan dilengkapi 16 bit ADC built-in sehingga dapat menghasilkan output sinyal digital berupa nilai intensitas cahaya

tanpa melalui perhitungan rumit. Modul sensor BH 1750 ini mampu mendeteksi jangkauan luas pada resolusi tinggi (1-65534 lx). (Abhinawa, A. T., 2021)



Gambar 2. 5 Sensor BH1750 (Cheddadi et al., 2020)

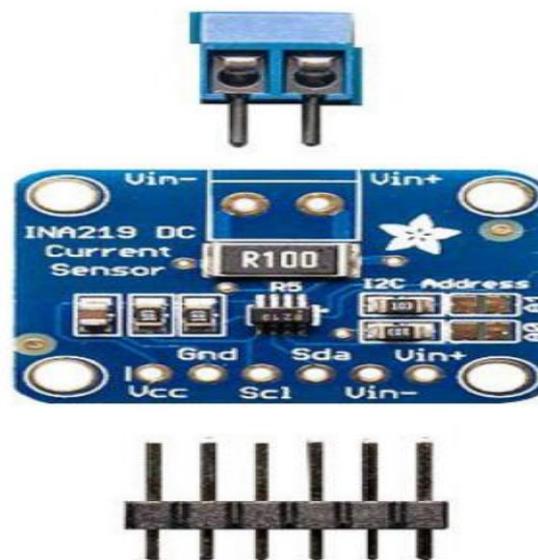
Pada gambar 2. 5 menunjukkan terdapat 5 pinout pada sensor BH1750 adalah sebagai berikut.

1. VCC (Voltage Supply): Ini adalah pin daya yang digunakan untuk memberikan tegangan pasokan ke sensor. Biasanya, tegangan pasokan adalah 3.3 V atau 5 V tergantung pada sensor yang digunakan.
2. SDA (Serial Data): Ini adalah pin data serial yang digunakan untuk mengirimkan data dari sensor ke mikrokontroler atau perangkat lain melalui antarmuka I2C (Inter-Integrated Circuit).
3. SCL (Serial Clock): Ini adalah pin clock serial yang digunakan dalam antarmuka I2C untuk mengatur waktu pengiriman data.
4. GND (Ground): Pin ini adalah pin tanah (ground), dan digunakan untuk menghubungkan sensor dengan tanah (ground) pada sumber daya yang sama dengan mikrokontroler.
5. ADD (Address): Pin ini digunakan untuk mengatur alamat I2C sensor BH1750. Dengan menghubungkan pin ADD ke tegangan positif (VCC) atau ke tanah (GND), dapat melakukan perubahan pada alamat I2C sensor.

2.12 Sensor INA219

Modul sensor INA219 merupakan sebuah Sensor arus dan tegangan digital yang digunakan untuk mengukur arus listrik yang mengalir pada suatu rangkaian dan tegangan yang diterapkan pada rangkaian tersebut. Pada sensor ini terdapat teknologi shunt resistor untuk mengukur arus dan ADC (Analog-to-Digital Converter) untuk mengukur tegangan. INA 219 didukung dengan interface I2C atau

SMBUS-COMPATIBLE dimana peralatan ini mampu memonitoring tegangan shunt dan suplai tegangan bus, dengan konversi program times dan filtering. INA 219 memiliki sebuah amplifier input maksimum adalah $\pm 320\text{mV}$ ini berarti dapat mengukur arus hingga $\pm 3,2\text{A}$. Dengan internal data 12 bit ADC, resolusi pada kisaran 3.2A adalah 0,8 mA. Dengan gain internal yang ditetapkan pada minimum div8, maks saat ini adalah $\pm 400\text{mA}$ dan resolusi 0,1 mA. INA 219 mengidentifikasi tegangan shunt pada bus 0 – 26 V (Instruments, T., 2015).



Gambar 2. 6 Sensor INA219 (Youssef Cheddadi et al., 2020)

Adapun fitur dari Sensor INA219 seperti pada tabel 2. 1 dibawah ini.

Tabel 2. 1 Fitur Sensor INA219 (Youssef Cheddadi et al., 2020)

Parameter	Value
Power Suply	3 to 5 V
Current detection resistor	0.1 O 1% 2 W
Measuring range : Voltage	Up to 26V
Measuring range : Current	Up to 3.2A
Resolution	0.8 mA
I2C addresses (on 7 bits):	0x40,0x41,0x44,0x45

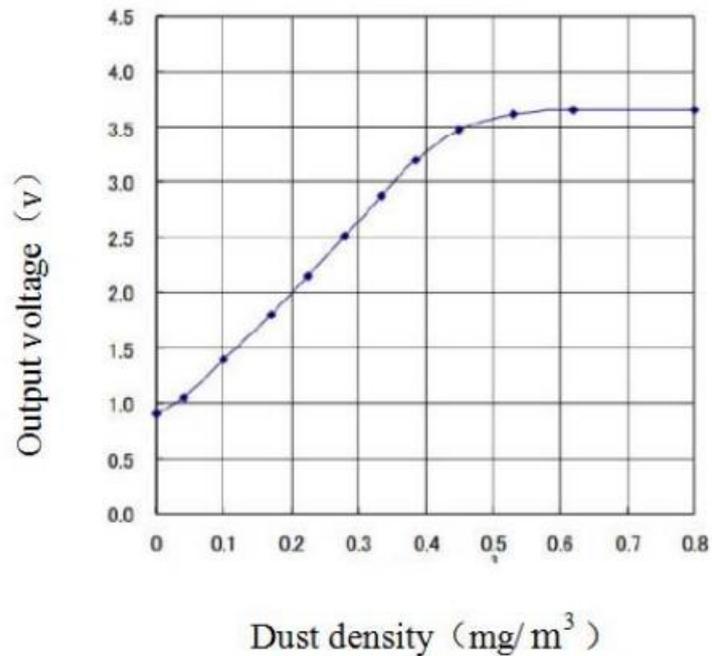
2.13 Sensor GP2Y1010AU0F

Modul sensor GP2Y1010AU0F menggunakan inframerah. Prinsip kerja dari sensor ini ialah dengan berdasarkan prinsip pemantulan cahaya. Sensor ini memiliki sebuah LED inframerah (IR) yang mengirimkan cahaya IR ke dalam udara. Ketika partikel debu atau partikulat terbang melalui cahaya IR, cahaya tersebut akan dipantulkan kembali ke sensor. Sensor akan mengukur intensitas pantulan cahaya oleh photodiode diubah menjadi tegangan untuk menentukan konsentrasi partikel di udara. Tegangan harus diperkuat untuk dapat membaca perubahan. Output dari sensor adalah tegangan analog yang sebanding dengan kepadatan debu yang terukur, dengan sensitivitas $0.5V/0.1 \text{ mg/m}^3$.



Gambar 2. 7 Sensor gp2y1010au0f

Menurut data teknis Sharp GP2Y1010AU0F, sensor ini bekerja dengan gelombang yang dipacu pulsa untuk menghidupkan dan mematikan LED inframerah. Dalam satu siklus selama 10 ms (yaitu 0,32 ms untuk menghidupkan LED inframerah dan kemudian 9,68 ms untuk mematikan LED tersebut). Sensor ini memiliki waktu pengambilan sampel sekitar 0,28 ms ketika LED sedang menyala.



Gambar 2. 8 Hubungan antara konsentrasi debu dan tegangan keluaran
(Li Y., dan He J., 2017)

Berdasarkan gambar 2. 8, sensor ini memiliki hubungan linear antara keluaran dan masukan, yaitu konsentrasi debu sebesar 0 hingga 0,5 mg/m³ sebagai masukan menghasilkan tegangan keluaran sebesar 0,6 hingga 3,5 volt. Oleh karena itu, regresi linear untuk hubungan antara konsentrasi debu dengan keluaran sinyal sensor dapat diperoleh dengan menggunakan persamaan berikut.

$$x = 0,16y - 0,1 \quad (2.5)$$

x adalah konsentrasi debu dan y adalah tegangan sinyal sensor. Namun, Persamaan (2) telah dibatasi untuk menghitung tegangan sinyal sensor hingga 3,5 volt untuk konversi unit yang lebih mudah. Dimana 3,5 volt mewakili konsentrasi debu sebesar 0,5 mg/m³, yang merupakan level bahaya sesuai dengan indeks pencemar standar di Indonesia (ISPU) (Rumantri R. et al., 2018).